文章编号:2096-1472(2024)03-0036-06

基于改进残差网络的拉丝机减速箱故障诊断

邹知成¹,万昌江^{1,2},汝 欣¹

(1.浙江理工大学机械工程学院,浙江 杭州 310018;
 2.浙江理工大学龙港研究院,浙江 温州 325000)
 ☑ Mixier1130@163.com; wanchj@zstu.edu.cn; ruxin@zstu.edu.cn



摘 要:减速箱对拉丝辊的转速固定有重要作用,由于拉丝设备结构紧密,内部零件的运行状态不易于观察,因 此减速箱轮齿故障导致的转速配比异常很难被及时发现,针对拉丝机减速箱存在的故障诊断环节缺失问题,提出一 种遗传算法与优化注意力模块改进的残差网络的故障诊断方法。首先,通过小波包分解与带通滤波的混合方法清 洗数据,依照生产车间实际情况提出综合评价指标,并按照指标需求选择小波包分解层数;其次,针对残差网络与注 意力模块进行改进;最后,将经过连通域分析与二值化后的特征图送入改进后的模型进行诊断。结果表明,该方法 的诊断准确率比注意力-残差网络模型(Squeeze-and-Excitation-ResNet, SE-ResNet)提升了 7.32%,比卷积神经网 络-极限学习机模型(Convolutional Neural Network-Extreme Learning Machine, CNN-ELM)提升了 8.81%,针对注 意力模块(Squeeze-and-Excitation Module, SE)的改进将模型的单次诊断时间在原来的基础上缩短 0.92 s,对塑编 拉丝车间中减速箱的维护具有较大的实用价值。

关键词:故障诊断;深度学习;遗传算法;挤压-激励模块;拉丝机;残差网络中图分类号:TP206.3 文献标志码:A

Fault Diagnosis of Wire Drawing Machine Reducer Based on Improved Residual Network

ZOU Zhicheng¹, WAN Changjiang^{1,2}, RU Xin¹

(1.School of Mechanical Engineering, Zhejiang Sci-Tech University, Hangzhou 310018, China;
2.Research Institute of Zhejiang Sci-Tech University in Longgang, Wenzhou 325000, China)
Mixien 1130@ 163.com; wanchj@zstu.edu.cn; ruxin@zstu.edu.cn

Abstract: The reduct plays an important role in fixing the speed of the wire drawing roller. Due to the compact structure of the drawing equipment and the difficulty in observing the operating status of internal parts, abnormal speed ratio caused by gearbox tooth faults is difficult to be found in time. To address the problem of missing fault diagnosis links in the reducer of the wire drawing machine, this paper proposes a fault diagnosis method based on genetic algorithm and improved residual network optimization attention module. Firstly, the data are cleaned by a hybrid method of wavelet packet decomposition and band-pass filtering. Comprehensive evaluation indicators are proposed based on the actual situation of the production workshop, and the number of wavelet packet decomposition layers is selected according to the indicator requirements. Secondly, the residual network and attention module are improved. Finally, the feature map after connected domain analysis and binarization is sent to the improved model for diagnosis. The results show that the diagnostic accuracy of the proposed method is 7.32% higher than that of traditional SE-ResNet (SE: Squeeze-and-Excitation), and 8.81% higher than that of CNN-ELM (Convolutional Neural Network-Extreme Learning Machine). The improvement of SE module shortens the single diagnosis time of the model by 0.92 s, which has great practical value for the maintenance of the reducer in the plastic weaving and drawing workshop.

Key words: fault diagnosis; deep learning; genetic algorithm; Squeeze-and-Excitation module; wire drawing machine; residual network

0 引言(Introduction)

拉丝机组的运行状况与塑料丝的成型高度相关。减速箱是

拉丝机传动系统中的关键部件,由于塑编拉丝车间生产流程长 且设备维护成本高,因此对减速箱进行故障诊断具有重要意义。

收稿日期:2023-06-08

基金项目:浙江省科技计划项目(2022C01065);浙江省基础公益研究计划项目(LGG21E050024)

从实际问题出发,立足于生产现场的数据量庞大的现状, 考虑到残差网络比经典卷积神经网络具有更加优秀的复杂特 征提取与表达能力,因此本研究采用残差网络作为模型基础, 针对拉丝车间的实际需求对残差网络的诊断准确率与单次诊 断速度进行改进。同时,拉丝车间的声音复杂度较高且设备长 时间在高温环境下工作,由于对扁丝产品不同性能的需求,机 筒等设备的工作温度需要经常调整,传统声发射方法与热成像 方法无法用于拉丝车间减速箱的故障诊断,因此选择使用振动 分析法对数据进行研究分析[1-4]。目前,深度学习在故障诊断 领域已取得较大发展[5-13]。熊剑等[14]把短时傅里叶变换与残 差网络结合建立诊断模型,其效果优于传统卷积网络。金列俊 等[15]省去特征提取与参数调优的步骤,直接使用一维卷积神 经网络对钻杆进行故障诊断。然而,以上方法均存在无法自更 新通道权重、超参数取值不是最优的问题,在特征提取效率与 诊断准确率方面仍有不足且未考虑实际使用场景下的诊断实 时性问题。

因此,本文提出一种基于振动信号的改进的残差网络,用 于拉丝车间减速箱的故障诊断。使用优化的挤压-激励模块与 遗传算法改进残差网络,并通过实验验证本文提出的诊断方法 的有效性与实用性。

1 故障诊断流程(Fault diagnosis process)

本研究中需要开展的故障诊断主要包含 6 个阶段:减速箱 振动信号的采集、对振动信号进行清洗提纯、将振动信号转化 为二维图像信息、对处理后的数据进行二值化与连通域分析组 成模型数据集、对残差网络(ResNet)的超参数进行优化以保证 最佳的识别效果、运用参数寻优后的网络进行故障诊断并展示 结果。故障诊断整体流程图如图 1 所示。



图1 故障诊断整体流程图



2 故障诊断模型(Fault diagnosis model)

2.1 小波包分解层数确认

根据对设备振动信号的分析,对原始信号进行傅里叶变

换,将信号转换到频域观察数据信号,如公式(1)所示。

$$F_{k} = \frac{1}{N} \sum_{n=0}^{N-1} x_{n} e^{-j\frac{2\pi kn}{N}}$$
(1)

其中: F_k 是频域上的信号序列, x_n 是时域上的信号序列,n 是 离散时间变量, $k(k=0,1,2,\dots,N-1)$ 是频率编号,N 是信号 长度。

重点关注啮合频率及其谐波附近的信号,如公式(2)所示。

$$F_{\rm GMF} = F_{\rm RF} \times N \tag{2}$$

其中: F_{GMF} 为齿轮啮合频率, F_{RF} 为齿轮转动频率,N为齿轮的齿数。

使用带通滤波器过滤掉低于 511 Hz 的信号与高于 1 600 Hz 的信号,但仅使用带通滤波器不能满足诊断准确率的要求,而 小波包分解具有压缩性与去噪性的特点,能关注并提取原始信 号的深层特征,因此将两种方法结合使用可以更好地提升诊断 速度与准确率。本文选择 Sym6 小波基函数对信号进行处理, 小波分解信号图如图 2 所示。



Fig. 2 Wavelet decomposition signal diagram

使用合适的小波包分解层数可以获得最佳的信号压缩过 滤效果。若小波包分解层数过高,会导致信号细节特征过多、 噪声的干扰增大,网络无法准确识别设备的阶段状态特征,导 致诊断准确率下降;若小波包分解层数过低,会出现特征提取 不充分、信息丢失、误差增加等现象。因此,需要通过实验验证 小波包分解的最优分解层数,具体的计算方法如下:

$$d_{l}^{j,2n} = \sum_{k} h_{k-2l} d_{k}^{j-1,n}$$
(3)

$$d_{l}^{j,2n+1} = \sum_{k} g_{k-2l} d_{k}^{j-1,n}$$
(4)

其中: $d_l^{j,2n}$ 、 $d_l^{j,2n+1}$ 为小波包系数, h_{k-2l} 、 g_{k-2l} 为小波包分解中的低通、高通滤波器组,j为尺度参数,l、k为平移参数,n为频率参数。

信号数据经过压缩过滤后,需要对信号进行重构,重构方 法如下:

$$\tilde{d}_{l}^{j,n} = \sum_{k} (\tilde{h}_{k-2l} d_{k}^{j+1,2n} + \tilde{g}_{k-2l} d_{k}^{j+1,2n+1})$$
(5)

其中: $\hat{d}_{l}^{i,m}$ 为小波包重构后的小波包系数, \hat{h}_{k-2l} 、 \hat{g}_{k-2l} 为小波 包重构的低通、高通滤波器组。

根据实际应用需求,考虑到拉丝流程紧凑且关联性强,一 旦出现故障会产生大量废丝,因此诊断反应速度与诊断准确率 是诊断性能的重要指标。结合企业对诊断反应速度的更高要 求,对诊断准确率与诊断反应速度给予不同权重,提出评价指 标ε,用以确定最终分解层数,具体公式如下:

$$\varepsilon = \frac{\alpha \theta + (0.1\tau)^{-1} \beta + M^{-1} \gamma}{3} \tag{6}$$

其中:ε 是分解评价指标;α 是准确率权重,取 0.4;β 是诊断时间权重,取 0.2;γ 是均方误差权重,取 0.4;θ 是当前小波包分解层数下的诊断准确率值,τ 是当前小波包分解层数下的单次诊断时间值,M 是归一化后的均方误差,通过将三个指标归一化到[0,1]上组成评价指标。

由表1可以看出,四层分解层数的综合评价指标最高,即 四层分解在能满足拉丝生产的实际需求的前提下,得到的重构 信号质量最优且对于原本信号的特征保留与信号去噪效果更 好。将水平与竖直方向上的信号以试序组成对应特征点,以每 1000组数据作为一张特征图的方式形成数据集,经过以上混 合处理方法,使原本冗杂、特征不明显的原始信号变得精简且 具有深层特征。对比信号处理前后的特征散点(图 3)可以发 现,经处理后的信号更紧凑,游离散点明显变少,状态特征表述 也更加清晰,将处理后的数据送入模型训练后,残差网络在故 障诊断时具有更高的准确率。

表1 不同分解层数的多个指标对比

Tab.1 Comparison of multiple indexes of different decomposition layers

分解层数	均方误差	平 均方误差 准确率/% 臣		评价指标
二层	0.209	86.66	1.32	0.78
四层	0.000 112	98.73	1.41	1.40
六层	0.143	95.72	1.64	0.80





2.2 网络模型建立

残差网络的堆叠残差块会引入不必要的冗余特征,这部分 冗余特征增加了诊断的时间,并降低了诊断准确率;残差网络 本身无法自适应地调节每个通道的重要性,所以仅依靠残差网 络进行诊断的准确率较低。为了解决以上问题,使用挤压-激 励模块对网络进行改进。挤压-激励模块能够学习到每个通道 的重要性权重,并且能根据这些权重自适应地调节特征图中的 每个通道,重要性较高的通道将得到更大的权重,从而更强烈 地影响最终的特征表示,而重要性较低的通道会得到较小的权 重,同时抑制冗余信息的表述,从而减弱其对最终特征表示的 影响,增强了残差网络的表达能力和特征选择能力。优化前后 的模型结构对比如图 4 所示。



(a)普通 ResNet 模块

(b)SE-ResNet 模块

图 4 优化前后的模型结构对比

Fig. 4 Comparison of model structure before and

after optimization

虽然挤压-激励模块优化了冗余特征的干扰,提升了计算 效率,但是在实际应用时必须让诊断的时间尽可能短,因此针 对模型的计算效率进行改进。针对 SE 模块进行改进能提升模 型的迁移性与通用性,具体改进方法是选择将计算效率更高的 ReLU 激活函数替换原本的激活函数。该改进方法可以降低 计算复杂度,并且 Sigmoid 函数在输入远离零时饱和,限制了 非线性表示能力的发挥,而 ReLU 函数则没有以上问题。

SE 模块的输出必须符合注意力权重的定义,即注意力权 重是一种概率分布,其值通常在[0,1]之间且所有权重的和为 1,而 ReLU 的输出为 Max(0,w^Tx+b),不符合注意力权重的 定义,因此需要再加入归一化操作,将输出限制在[0,1]之间, 使之符合注意力权重的定义。改进的挤压-激励模块结构如 图 5 所示。





首先,输入的特征图与传统 SE 模块的特征图处理方式相同,进行卷积与压缩得到具有全局感受野的特征输出 z_e,其公式如下:

$$z_{\varepsilon} = F_{\mathrm{sq}}(u_{\varepsilon}) = \frac{1}{W \times H_{i=1}} u_{\varepsilon}(i,j)$$
(7)

其中: z_c 是输出的特征值, c是通道数, u_c 是输入特征图, H、W是特征图的高与宽, i、j是特征数据行与列。

其次,进行激励操作,将特征输出进行特征降维并使用 ReLU激活,再进行一次全连接层升维回到原来的维度,该操 作可以极大地减少参数量与计算量,并且更好地拟合通道间的 相关性。之后,不再使用 Sigmoid 激活函数获取权重,而是通 过 ReLU激活函数与归一化操作获得特征权重,其公式如下:

$$s = F_{ex}(x, W)$$
$$= P(g(x, W))$$
$$= P(W_2\delta(W_1z))$$

(8)

其中: F_{ex} 为激励操作,s为特征权重,P为 Softmax 归一化, δ 为 ReLU 激活函数, W_1 、 W_2 为两个全连接层的权值矩阵。

把特征权重与原始特征数据相乘,得到通道注意力加权输 出特征图,其公式如下:

$$\widetilde{x}_{c} = F_{\text{scale}}(u_{c}, s_{c}) = s_{c}u_{c}$$
(9)

其中: F_{scale} 为标定操作, u_c 为特征图中的第c 个通道, s_c 为权重矩阵的第c 个通道。

经过多次实验,优化前后的模型诊断准确率的差距在1% 以内,但单次诊断时间相差0.92 s。可见,针对 SE 模块的改进,在遗传算法-注意力-残差网络(GA-SE-ResNet)提速效果较好的前提下,准确率没有出现大幅度波动。优化前后模型性能对比如表2所示。

表2 优化前后模型性能对比

Tab.2 Comparison of model performance before and

after optimization

激活 函数	平均诊断 时间/s	最长诊断 时间/s	最短诊断 时间/s	平均准确 率/%
ReLU	0.66	0.69	0.64	98.02
Sigmoid	1.58	1.80	1.39	98.04

2.3 基于遗传算法的超参数优化

模型的性能与超参数的选择也有较大的关系,传统诊断模型的超参数通常依靠人工经验指定,这种方式的不确定性高且无法保证模型性能最优,因此引入遗传算法(GA 算法)确定模型最优超参数的取值,寻优流程如图 6 所示。由于网络准确率是由超参数的组合决定的,因此将 GA 算法的适应度函数设置为网络准确率的反比例函数,寻优过程也是对最优的网络性能的寻找,将两种算法结合,可以解决 ResNet 网络的超参数无法保证最优的问题。



Fig. 6 Optimization flow

首先,确定遗传算法的适应度函数,用于衡量个体在解决 问题中的优劣程度。引入遗传算法的目的是使用最优的超参 数使残差网络的准确率最高,因此适应度函数设置为网络准确 率的反比例函数,最小的适应度值对应的基因组就是模型所需 的最优超参数组合,计算公式如下:

 $Fitness = Net_acc \{ R(lr_i, bs_i, Mm_i, Wd_i) \}$ (10) 其中:R为残差网络模型, lr_i 为学习率, bs_i 为批处理数, Mm_i 为动量, Wd_i 为权重衰减。

其次,设置各个参数的寻优区间,作为遗传算法的基因库, 如表 3 所示。

表3 指定参数取值区间

Tab.3 Specified parameter value range

寻优参数	寻优区间		
Batch_size	{32,64,128,256}		
Momentum	[0.90,0.94]		
Learning_rate	[0.01,0.10]		
Weight_decay	[0.000 1,0.000 5]		

选择合理的算子与编码方式可以提升算法的性能。为了 增强算法的局部搜索能力与计算效率,选择使用格雷码编码, 选择算子使用轮盘赌值,交叉算子采用单点交叉,单点交叉能 保证基因组的完整性,加强算法的局部搜索能力与计算效率。 设置种群数量为100个、最大迭代次数50次,当GA算法收敛 时,将在表3的区间与数组内寻找到最优的个体基因组。

3 实验结果(Experimental result)

将生产现场使用的 EUGENE 工业斜减速箱作为待测对 象,使用 CYT9350 加速度传感器与 USB-1252A 数据采集卡作 为采集设备,减速箱啮合频率为 511 Hz,设置采样频率为 5 120 Hz。实验振动数据由采集模块获取,所有状态振动数据 总数为 600 000 条,单个方向的单状态数据为 100 000 条,以每 1 000 个数据对作为一组,共分为 100 组,经过二维特征化形成 单状态数据量,共 100 张;再通过对图片随机添加噪点、平移等 操作扩充数据,扩充后单状态数据量为 347 张,总数据量为 1 043 张,按照 8:1:1 的比重分为训练集、验证集、测试集。

GA 算法输出的最优超参数组合如表 4 所示, 网络在进行 训练时使用对应最优参数, 保证达到模型最佳的诊断效果, 并 与传统网络的准确率进行对比。

Tab.4 Model hyperparameter optimization results

寻优参数	最优参数		
Batch_size	32		
Momentum	0.91		
Learning_rate	0.015		
Weight_decay	0.000 34		

如表 5、图 7 所示,从准确率方面来看,改进后的 GA-SE-ResNet 比传统的 SE-ResNet 平均诊断准确率提升 7.32%、迭 代次数减少 11 次,并且 SE-ResNet 的超参数是随机指定的,导 致准确率波动大,其最高诊断准确率与最低诊断准确率相差 5.25%;相比 CNN-ELM,平均诊断准确率提升 8.81%、迭代次 数减少 8 次,同样由于无法保证参数最优,导致准确率存在较 大波动;相比遗传算法-支持向量机(GA-SVM),平均诊断准确 率提升 0.7%,迭代次数减少 6次,其整体准确率波动不大。从 单次诊断时间来看,得益于改进 SE 模块的速度优化,改进后的 GA-SE-ResNet 模型较改进前的平均诊断时间缩短了 0.92 s; 由于传统 ResNet 网络引入残差连接增加了计算量,导致单次 诊断时长比传统卷积神经网络(CNN)网络更长,通过改进挤 压-注意力模块将单次诊断时间缩短至与 CNN 相近的水平。

表5 不同模型下的诊断准确率

Tab.5 Diagnostic accuracy under different models

模型	最高准 最低准 确率/% 确率/%		平均准 确率/%		平均诊断 时间/s		
CNN-ELM	91.73	91.73 86.66		89.21		0.57	
SE-ResNet	93.33	88.08		90.70		1.25	
GA-SVM	97.78	96.86		97.32		0.64	
改进前的 GA-SE-ResNet	98.77	97.32		98.04		1.58	
改进后的 GA-SE-ResNet	98.76	97. 32		98.02		0.66	
		1009/					-100
0- 93.6% 0%	13.7%	75%	_ 0 -	100%	2.2%	4.4%	-75%
0% 100%	0% -5	50%	ue Labe	0%	97.8%	0%	-50%
2= 6.4% 0%	86.3%	25%	F 2-	0%	0%	95.6%	-25%
Predicted Label		J%0		0 P	1 2 Predicted Label		070
(a)SE-ResNet				(b)GA-SVM			
		100%	_				-1009
0 = 98.7% 0%	4.2%	75%	-0-	100%	0%	2.6%	-75%
1 - 0% 100%	0% -	50%	ie Labe	0%	100%	0%	-50%
<u>=</u> 2- 1.3% 0%	95.8%	25%	Ê	0%	0%	96.2%	-25%
0 1 Predicted	2 Label	0%		0 P	1 redicted I	2 abel	-0%
(c)CNN-FI M			(d)改进后的 GA-SF-ResNet				

图 7 混淆矩阵

Fig. 7 Confusion matrix

如图 8 所示,针对特定车间的运行数据,GA-SVM 在所有 模型中损失值较小,在前 4 次迭代,它的收敛速度比优化后的 GA-SE-ResNet 更快,在 4 次迭代后其收敛速度渐慢于改进后 的残差模型;得益于极限学习机的高效计算效率与训练速度, CNN-ELM 模型的收敛速度是所有模型中最快的,但缺点是损 失值较大,诊断准确率不高;普通 SE-ResNet 模型损失值相较 于 CNN 虽然更小,但是收敛轮次是所有模型中最多的,并且准 确率不稳定,一方面是因为残差模型的计算量较大,另一方面 是因为模型的参数不是最优,导致收敛速度慢。得益于遗传算 法得到的最优参数与改进 SE 模块的更高的计算效率,改进后 的残差模型无论在收敛轮次还是损失值大小方面,在以上模型 中都是最优的,优化后单次诊断时间也获得较大的提升,由混 淆矩阵可以看出,该模型对拉丝车间减速箱健康与磨损状态下 的诊断效果较好。

实验结果说明,在塑编拉丝车间减速箱的故障诊断上,相较于 CNN-ELM、SE-ResNet、GA-SVM 等模型,改进后的 GA-SE-ResNet 模型效果更优。



Fig. 8 Loss value curve

4 结论(Conclusion)

为了提升塑编拉丝车间的智能化改造水平,实现对拉丝关 键部件的故障诊断,构建了针对拉丝车间的基于残差网络改进 模型的故障诊断方法。根据拉丝车间的特点,通过信号双方向 采集融合、信号二维化、数据点连通域分析等方法对信号进行 预先处理,由于拉丝工艺对诊断的响应时间有较高要求,因此 针对 GA-SE-ResNet 模型的单次诊断时间较长的问题,进 改进挤压-激励模块的结构。实验结果表明,改进后的 模型的 单次诊断时间缩短了 0.92 s,实际诊断时间相较于改进前大幅 度减少,在诊断准确率保持稳定的前提下 了诊断实时性, 更符合实际诊断场景下的实时性需求 使用遗传算法选 择最优的残差网络超参数组合,解决 ,差网络无法自适应调 节参数的问题,同时避免人工设置超参数导致模型可靠性不足 的问题。实验结果表明,该模型针对拉丝车间的诊断性能优 秀。该模型为拉丝机关键部件的故障检测提供了一种新的方 案,对车间智能化水平的提升具有积极意义。

参考文献(References)

- [1]周玉蓉,张巧灵,于广增,等.基于声信号的工业设备故障 诊断研究综述[J]. 计算机工程与应用,2023,59(7): 51-63.
- [2] NING D Y, SUN C L, GONG Y J, et al. Extraction of fault component from abnormal sound in diesel engines using acoustic signals[J]. Mechanical systems and signal processing, 2016, 75:544-555.

- [3] KARABACAK Y E, GÜRSEL ÖZMEN N, GÜMÜŞEL L. Worm gear condition monitoring and fault detection from thermal images via deep learning method[J]. Eksploatacja i niezawodność-maintenance and reliability, 2020, 22(3): 544-556.
- [4] 司伟伟,岑健,伍银波,等.小样本轴承故障诊断研究综述 [J]. 计算机工程与应用,2023,59(6):45-56.
- [5] 翟嘉琪,杨希祥,程玉强,等. 机器学习在故障检测与诊断 领域应用综述[J]. 计算机测量与控制,2021,29(3):1-9.
- [6] 賀政,曹宏斌,赵富强. 基于混合遗传算法的 10 kV 避雷器 劣化状态识别仿真[J]. 微型电脑应用,2023,39(11): 69-72.
- [7] 余萍,曹洁. 深度学习在故障诊断与预测中的应用[J]. 计 算机工程与应用,2020,56(3):1-18.
- [8] 侯林涛,阎俏,张桂青,等. 基于 K-means 算法的光伏路灯 蓄电池故障识别研究[J]] 计算机时代,2023(6):114-118.
- [9] 赵师兵,张志明 基于时域信号特征和卷积神经网络的模 拟电路故障诊断算法[J]. 计算机应用,2022,42(增刊 2): 320-326

[19] 雷泽临,苏俭,郭伟. 基于机器学习的蜂窝网络故障管理 框架及方法综述[J]. 计算机应用研究,2022,39(12): 3521-3533.

- 赵晓平,彭澎,张永宏,等.改进孪生网络在小样本轴承故 障诊断中的应用[J].计算机工程与应用,2023,59(19): 294-304.
- [12] 张弛,王广民,许会博,等. 基于 PCA 和优化参数 SVM 的 智能变电站故障诊断方法[J]. 计算机应用与软件,2022, 39(7):80-88.
- [13] 郭秀才,刘冰冰,王力立.基于小波包和 CS-BP 神经网络的矿用电力电缆故障诊断[J].计算机应用与软件,2021, 38(9):105-110.
- [14] 熊剑,邓松,时大方. 基于改进残差网络的滚动轴承故障 诊断[J]. 轴承,2020(11):50-55.
- [15] 金列俊, 詹建明, 陈俊华, 等. 基于一维卷积神经网络的钻 杆故障诊断[J]. 浙江大学学报(工学版), 2020, 54(3): 467-474.

作者简介:

- 邹知成(1997-),男,硕士生。研究领域:智能制造。
- **万**昌江(1972-),男,博士,讲师。研究领域:精益生产及信息系 统开发。本文通信作者。
- 汝 欣(1989-),女,博士,讲师。研究领域:机械工程,现代纺织 装备技术,计算机辅助设计。